



University Of Qom



Estimation of the Downstream Scour Depth of Vertical Drop Using the Support Vector Machine (SVM) Algorithm

Hossein Mohammadnezhad¹, Mirali Mohammadi^{2✉} , Mohammad Bagherzadeh³ 

1. Department of Civil Engineering, Faculty of Engineering, Urmia University, Urmia, Iran. E-mail: mohammadnezhad.hossein@gmail.com
2. Corresponding author, Department of Civil Engineering, Faculty of Engineering, Urmia University, Urmia, Iran. E-mail: m.mohammadi@urmia.ac.ir
3. Department of Civil Engineering, Faculty of Engineering, Urmia University, Urmia, Iran. E-mail: m.bagherzadeh@urmia.ac.ir

Article Info

Article type:

Research Article

Article history:

Received 13 May 2022

Revised 17 Aug 2022

Accepted 28 Aug 2022

Keywords:


Scour Depth,
Vertical Drop,
Tailwater Depth,
Densimetric Froude
Number,
Support Vector Machine.

ABSTRACT

The downstream scour of the vertical drop can be one of the causes of instability and failure of this structure. In the present study, the downstream scour depth of this structure predicted using the support vector machine (SVM) method. For this purpose, 104 experimental data used to estimate the scour depth. These data are a function of the two dimensionless parameters of densimetric Froude number (Fr_j) and tailwater depth (y_t/y_j) that have been entered into the SVM in three different models. To evaluate the results, the evaluation criteria of R^2 , NRMSE, DC, and MARE used. The results showed that model number (1) with the input combination (Fr_j and y_t/y_j) with $R^2=0.9777$, $DC=0.929$, $NRMSE=0.0775$, and $MARE=11.89\%$ for the test stage leads to the best result. The SVM method also has appropriate accuracy, acceptable results, and desirable performance in estimating the scour depth. Also, it was found that the densimetric Froude number has a greater effect on estimating the relative scour depth compared to the tailwater depth.

Cite this article: Mohammadnezhad, Hossein., Mohammadi, Mirali., & Bagherzadeh, Mohammad. (2023). Estimation of the Downstream Scour Depth of Vertical Drop Using the Support Vector Machine (SVM) Algorithm. *Civil Infrastructure Researches*, 9(1), 1-11. <https://doi.org/10.22091/cer.2022.8208.1395>





تخمین عمق آبستگی پایین دست شیب‌شکن قائم با استفاده از الگوریتم ماشین بردار پشتیبان

حسین محمدنژاد^۱، میرعلی محمدی^۲، محمد باقرزاده^۳

۱. گروه مهندسی عمران، دانشکده فنی، دانشگاه ارومیه، ارومیه، ایران. رایانامه: mohammadnezhad.hossein@gmail.com
۲. نویسنده مسئول، گروه مهندسی عمران، دانشکده فنی، دانشگاه ارومیه، ارومیه، ایران. رایانامه: m.mohammadi@urmia.ac.ir
۳. گروه مهندسی عمران، دانشکده فنی، دانشگاه ارومیه، ارومیه، ایران. رایانامه: m.bagherzadeh@urmia.ac.ir

چکیده

آبستگی پایین دست شیب‌شکن قائم می‌تواند یکی از عوامل ناپایداری و خرابی این سازه باشد. در تحقیق حاضر، عمق آبستگی پایین دست شیب‌شکن قائم با استفاده از روش ماشین بردار پشتیبان (SVM) پیش‌بینی شده است. بدین منظور، برای تخمین عمق آبستگی پایین دست شیب‌شکن قائم، ۱۰۴ داده آزمایشگاهی مختلف مورد استفاده قرار گرفته است. این داده‌ها تابعی از دو پارامتر بدون بُعد عدد فرود ذرات رسوبی (Fr_j) و عمق نسبی پایاب (y_i/y_j) می‌باشند که در سه مدل متفاوت وارد شبکه ماشین بردار پشتیبان شده‌اند. جهت ارزیابی نتایج حاصل، معیارهای ارزیابی ضریب تعیین (R^2)، جذر میانگین مربعات نرمال‌سازی شده خطاها (NRMSE)، ضریب کارایی (DC) و میانگین قدر مطلق خطای نسبی (MARE) به کار برده شده‌اند. نتایج نشان داد مدل شماره (۱) با ترکیب ورودی (y_i/y_j و Fr_j) با داده‌های آماری $R^2=0.9777$ ، $DC=0.929$ ، $NRMSE=0.0775$ و $MARE=11.89\%$ برای مرحله آزمون منجر به حصول بهترین نتیجه می‌شود و روش SVM نیز در تخمین عمق نسبی آبستگی از دقتی مناسب، نتایجی مقبول و عملکردی مطلوب برخوردار است. همچنین، مشخص شد که پارامتر Fr_j تأثیر بیشتری بر تخمین عمق نسبی آبستگی در مقایسه با عمق نسبی پایاب دارد.

اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۱/۰۲/۲۳

تاریخ بازنگری: ۱۴۰۱/۰۵/۲۶

تاریخ پذیرش: ۱۴۰۱/۰۶/۰۶

کلیدواژه‌ها:

آبستگی،
شیب‌شکن،
عمق پایاب،
عدد فرود ذره رسوبی،
شبکه SVM.

استناد: محمدنژاد، حسین؛ محمدی، میرعلی؛ و باقرزاده، محمد. (۱۴۰۲). تخمین عمق آبستگی پایین دست شیب‌شکن قائم با استفاده از الگوریتم

ماشین بردار پشتیبان. پژوهش‌های زیرساخت‌های عمرانی، ۹(۱)، ۱-۱۱. <https://doi.org/10.22091/cer.2022.8208.1395>



۱- مقدمه

پایین دست شیب شکن قائم با رسوبات غیریکنواخت را بررسی نموده و نشان دادند که با افزایش پارامتر غیریکنواختی رسوبات، عمق آبستنگی کاهش می‌یابد [۱۱]. محققان آبستنگی پایین دست یک شوت مانع دار را بررسی نموده و معادلاتی برای حداکثر عمق آبستنگی ارائه نمودند [۱۲]. همچنین در تحقیقی دیگر، آبستنگی پایین دست شیب شکن قائم با بستر بالادست شیب دار بررسی گردیده و معادلاتی جهت تخمین حداکثر عمق آبستنگی پیشنهاد شد [۱۳]. ملکی و فیوروتو^۷ نیز به بررسی آبستنگی در پایین دست یک جت سطحی پرداخته و تأثیر هوا در ارزیابی عمق آبستنگی را در نظر گرفتند [۱۴].

طی دهه اخیر، با پیشرفت در حوزه فناوری، محققین حوزه هیدرولیک نیز بجای انجام آزمایش‌های وقت گیر و پرهزینه، به استفاده از رایانه‌ها در تحلیل رخدادهای هیدرولیکی پرداخته‌اند. لذا اکثر تحقیقات هیدرولیکی با استفاده از روش‌های متفاوت هوش مصنوعی مانند شبکه‌های عصبی مصنوعی (ANN^۸)، برنامه‌ریزی بیان ژن (GEP^۹)، رگرسیون تعمیم یافته شبکه‌های عصبی مصنوعی (GRNN^{۱۰})، سیستم استنتاج عصبی- فازی تطبیقی (ANFIS^{۱۱}) و ماشین بردار پشتیبان (SVM^{۱۲})، در زمینه تخمین رفتار پارامترهای هیدرولیکی سازه و هیدرولوژی صورت پذیرفته است.

آکب^{۱۳} و همکاران عمق آبستنگی در پایه‌های پل‌ها با استفاده از روش‌های رگرسیون خطی و ANFIS را بررسی کردند، که نتایج روش ANFIS نسبت به روش رگرسیون خطی ساده، برتر بود [۱۵]. روشنگر و کوشه^{۱۴} نیز بار انتقالی بستر را با استفاده از روش SVM تخمین

در کانال‌های آبرسانی، معمولاً در انتقال آب از ارتفاع بالا به پایین، جهت کنترل انرژی و سرعت آب و جلوگیری از افزایش بی‌رویه شیب کف کانال، از شیب شکن‌های قائم استفاده می‌شود. علاوه بر آن، برای اکسیژن‌دهی به آب و کنترل فرسایش نیز این سازه‌ها کاربرد دارند. نکته مهم در طراحی این سازه‌ها این است که هرچند به دلیل اختلاط و تلاطم ایجاد شده در استخر پایین دست این سازه، مقدار قابل توجهی از انرژی جریان مستهلک می‌شود، ولی به واسطه فرسایش بستر پایین دست این سازه، ناشی از برخورد و انتشار جت ریزشی، پایداری آن در معرض خطر قرار می‌گیرد [۱].

اولین تحقیق در خصوص شیب شکن قائم را می‌توان به باخمتف^۱ نسبت داد [۲]. پس از ایشان، اثر پارامترهای هیدرولیکی جریان روی شیب شکن قائم توسط محققینی همچون رند^۲، گیل^۳ و راجاراتنام و چمنی^۴ مورد بررسی و ارزیابی قرار گرفت [۳، ۴ و ۵]. پژوهشگران دیگری تأثیر پله چسبیده به دیواره شیب شکن را بر افزایش استهلاک انرژی جریان گزارش نمودند [۶]. هانگ^۵ و همکاران با در نظر گرفتن شیب مثبت در بالادست سازه به بررسی نیروی وارد بر بستر پایین دست شیب شکن در اثر برخورد جت ریزشی پرداختند [۷]. در تحقیقی دیگر نیز گزارش شد که شیب بالادست شیب شکن، زاویه برخورد جت ریزشی را کاهش می‌دهد [۸].

محققان آبستنگی پایین دست سازه شیب شکن قائم با رسوبات چسبنده را مورد بررسی قرار دادند [۹]. دی و رایکار^۶ با بررسی آبستنگی پایین دست شیب شکن قائم نشان دادند که افزایش عمق پایاب، عمق آبستنگی را کاهش می‌دهد [۱۰]. قدسیان و همکاران آبستنگی

⁷- Maleki and Fiorotto

⁸- Artificial Neural Networks

⁹- Gene Expression Programming

¹⁰- General Regression Neural Network

¹¹- Adaptive Neuro Fuzzy Inference System

¹²- Support Vector Machine

¹³- Akib

¹⁴- Koosheh

¹- Bakhmeteff

²- Rand

³- Gill

⁴- Rajaratnam and Chamani

⁵- Hong

⁶- Dey and Raikar

پایداری سازه شیب‌شکن قائم در مقابل فرسایش بستر پایین‌دست ناشی از برخورد جت ریزشی آن از اهمیت بسزایی برخوردار است. از طرفی در سال‌های اخیر روش‌های محاسبات نرم برای شبیه‌سازی رفتار سیستم‌ها در علوم مهندسی آب بیشتر مورد استفاده قرار گرفته است. بنابراین، در تحقیق حاضر، برای اولین بار از مدل SVM به منظور تخمین عمق آبشستگی پایین‌دست سازه شیب‌شکن قائم استفاده گردید. نتایج حاصل از پیش‌بینی، مورد ارزیابی قرار گرفته و با داده‌های آزمایشگاهی صحت‌سنجی شده است.

۲- مواد و روش‌ها

۲-۱- تحلیل ابعادی

مطابق شکل ۱، پارامترهای مؤثر بر عمق آبشستگی پایین‌دست شیب‌شکن قائم (d_{se}) به صورت رابطه (۱) بیان می‌شود:


$$d_{se} = f_1(q, y_j, y_t, \Delta g, v, d_{50}) \quad (1)$$

که در آن، q دبی در واحد عرض، y_j ضخامت جت در برخورد با عمق پایاب، y_t عمق پایاب، Δg ترکیب پارامترهای g شتاب گرانش، ρ_s چگالی ذرات رسوبی، ρ چگالی آب، $\Delta = s - 1$ و $v = \rho_s / \rho$ ویسکوزیته جنبشی و d_{50} اندازه متوسط ذرات رسوبی است. با استفاده از قضیه Pi باکینگهام و انتخاب y_j و q به عنوان پارامترهای تکراری، رابطه (۲) حاصل گردید:

$$\frac{d_{se}}{y_j} = f_2\left(\frac{q}{v}, \frac{y_t}{y_j}, \frac{q}{y_j \sqrt{\Delta g y_j}}, \frac{d_{50}}{y_j}\right) \quad (2)$$

در آن، d_{se}/y_j عمق نسبی آبشستگی، q/v عدد رینولدز در محل برخورد جت به عمق پایاب (Re_j)، y_t/y_j عمق نسبی پایاب، $q/y_j \sqrt{\Delta g y_j}$ معرف عدد فرود و d_{50}/y_j قطر نسبی ذرات رسوبی یا زبری نسبی است.

زدند. مقایسه نتایج بدست آمده با روابط تجربی حاکی از برتری SVM در مقایسه با روابط تجربی است [۱۶]. محققان دیگری، برای تخمین عمق آبشستگی اطراف پایه‌های مرکب، از روش SVM استفاده کردند. معیارهای ارزیابی نتایج این روش شامل $R^2=0.85$ و $MARE=0.216$ می‌باشد [۱۷]. نادرپور و همکاران با استفاده از شبکه عصبی مصنوعی به پیش‌بینی مقاومت فشاری بتن دوستدار محیط زیست پرداختند. نتایج نشان داد که روش ANN در میان دیگر روش‌ها به خوبی مقاومت فشاری بتن را پیش‌بینی نمود [۱۸]. شبیه‌سازی عمق آبشستگی پایه‌های پل با هندسه‌های متفاوت با سه روش SVM، GEP و مدل رگرسیون غیرخطی توسط ماجدی‌اصل و همکاران انجام شد. نتایج نشان داد که SVM در مقایسه با دو روش دیگر، پیش‌بینی بهتر و عملکرد مناسبی در تخمین عمق آبشستگی دارد [۱۹]. تخمین پارامترهای هیدرولیکی در شیب‌شکن قائم مجهز به صفحات مشبک افقی دوگانه و همچنین صفحات مشبک با قطرهای متفاوت با استفاده از SVM توسط دانشفراز و همکاران انجام گرفت. نتایج این مطالعات نشان داد که SVM می‌تواند به خوبی پارامترهای هیدرولیکی این نوع شیب‌شکن‌های قائم را پیش‌بینی نماید [۲۰] و [۲۱]. شبیه‌سازی عددی و کاربرد محاسبات نرم در تخمین استهلاک انرژی شیب‌شکن قائم با لبه دندان‌های افقی توسط باقرزاده و همکاران انجام گرفت. نتایج پیش‌بینی استهلاک انرژی با استفاده از روش‌های ANN، SVM و GEP نشان داد که هر سه مدل دارای دقت مناسبی جهت تخمین استهلاک انرژی می‌باشند، اما دقت روش ANN با مقادیر $RMSE=0.0125$ و $R^2=0.9805$ برای حالت تست در مقایسه با دو روش دیگر بیشتر است [۲۲]. اسدی و همکاران با بررسی موضوع تأثیر شکاف بر روی حفره آبشستگی پایین‌دست سرریزها دریافتند که استفاده از روش رگرسیون بردار پشتیبان می‌تواند مقادیر دقیق حفره آبشستگی را تخمین بزند [۲۳].



شکل ۱- عمق آبستگي پايين دست شيبشکن قائم [۱۰]

مدل SVM^{۱۵} از جمله روش‌های یادگیری با نظارت^{۱۶} می‌باشد که اولین بار توسط واپنیک^{۱۷} برای حالت غیرخطی تعمیم داده شد. این الگوريتم در زمینه حل مسائل طبقه‌بندی و پیش‌بینی از روش رگرسیونی استفاده می‌کند و همانند شبکه‌های عصبی مصنوعی، مراحل حل مسائل به دو مرحله آموزش و آزمون (صحت‌سنجی) تقسیم می‌گردد. مبنای کار SVM دسته‌بندی خطی داده‌ها می‌باشد و سعی بر این است که در تقسیم خطی داده‌ها، خطی در نظر گرفته شود که حاشیه اطمینان بالایی دارد. تئوری SVM طبقه‌بندی و جداسازی خطی داده‌ها می‌باشد. در صورت خطی بودن داده‌ها، جهت تفکیک آن‌ها سعی بر این است که صفحه‌ای با حداکثر حاشیه^{۱۸} انتخاب شود (مطابق شکل ۲). اندازه حاشیه صفحه جداکننده با استفاده از رابطه (۴) به دست می‌آید [۲۴ و ۲۵]:

$$Margin = \frac{2}{\|w\|} = \frac{2}{w^T w} \quad (4)$$

از آنجا که بهترین صفحه جداکننده دارای بیشترین فاصله بین دو کلاس (ابتدا و انتهای حاشیه) در شکل ۲ خواهد بود، لذا $\|w\|$ بایستی حداقل مقدار را به خود اختصاص دهد. پس معادله کلی صفحه بهینه به صورت رابطه (۵) بیان می‌شود [۲۴ و ۲۶]:

$$w^T x + b = 0 \quad (5)$$

با تقسیم عدد فرود بر ریشه قطر نسبی ذرات رسوبی، می‌توان عدد فرود ذره رسوبی به صورت $Fr_j = q / y_j \sqrt{\Delta g d_{50}}$ تعریف می‌شود. از تأثیر عدد رینولدز مطابق مطالعات آزمایشگاهی صرف نظر گردید. همچنین، از آنجایی که عدد فرود ذره رسوبی (Fr_j) خود شامل قطر نسبی ذرات رسوبی است، لذا رابطه (۲) به صورت زیر ساده می‌شود:

$$\frac{d_{se}}{y_j} = f_3\left(\frac{y_t}{y_j}, Fr_j = \frac{q}{y_j \sqrt{\Delta g d_{50}}}\right) \quad (3)$$

۲-۲- داده‌های آزمایشگاهی مورد استفاده

به منظور بررسی عملکرد الگوريتم SVM در تخمین عمق آبستگي شيبشکن قائم، از داده‌های آزمایشگاهی دی و رایکار که در سال ۲۰۰۷ انجام شده است، استفاده گردید [۱۰]. آن‌ها آزمایش‌های خود را روی یک شيبشکن قائم به ارتفاع ۰/۲۵ و عرض ۰/۳ متر انجام دادند. بستر رسوبی در نظر گرفته شده در تحقیق آن‌ها دارای طول ۱/۱ و ارتفاع ۰/۲۵ متر، با اندازه ذرات رسوبی ۰/۲۶ تا ۷/۱۵ میلی‌متر می‌باشد. آزمایش‌های آن‌ها در محدوده دبی جریان ۰/۷۵ تا ۱۳ لیتر در ثانیه و برای عمق پایاب ۸ تا ۲۲ سانتی‌متر انجام گردیده است. در تحقیق حاضر، از سه نوع داده عمق آبستگي (در مجموع تعداد ۱۰۴ داده) برای دبی ثابت ۳ لیتر در ثانیه با اندازه ذرات ۰/۸۱ و ۵/۵۳ میلی‌متر و عمق پایاب مختلف استفاده شده است.

۳-۲- مدل SVM

¹⁵- Support vector machine

¹⁶- Supervised Learning

¹⁷- Vapnik

¹⁸- Margin


۲-۴- الگوریتم جنگل تصادفی

الگوریتم جنگل تصادفی (RF^{۲۱}) یک الگوریتم یادگیری تجمعی برای مسائل مبتنی بر رگرسیون و گروه‌بندی براساس توسعه درخت تصمیم ارائه شده است [۲۶]. یک جنگل تصادفی، مجموعه‌ای از درخت‌های هرس نشده است که هر درخت با الگوریتم جزءبندی بازگشتی حاصل می‌شود. به عبارتی، جنگل تصادفی ترکیبی از چندین درخت تصمیم است که در ساخت آن چندین نمونه خودسازمانده از داده‌ها شرکت دارند. روش خودسازمانده، روش نمونه‌گیری با جاگذاری است؛ یعنی هیچکدام از داده‌های انتخاب شده از نمونه‌های ورودی برای تولید زیرمجموعه بعدی حذف نمی‌شوند. بنابراین برخی از داده‌ها ممکن است بیش از یک بار در شاخه‌های آموزشی استفاده شوند و برخی دیگر که در مدل‌سازی تأثیر چندانی ندارند هرگز استفاده نمی‌شوند [۲۷]. برای نمونه خودسازمانده انتخابی، یک درخت کلاس‌بندی با استفاده از الگوریتم جزءبندی بازگشتی رشد می‌کند. در هر گره، عمل تجزیه مبتنی بر یک نمونه تصادفی از تعداد متغیر پیش‌بینی است. الگوریتم تجزیه بازگشتی آنچنان ادامه می‌یابد تا درخت به بزرگترین اندازه خود برسد، بدون آن‌که درخت هرس شود [۲۶].

۲-۵- روند ارزیابی کارایی مدل‌ها

برای انجام اهداف تحقیق حاضر از نرم‌افزار استاتیسکا ۱۰^{۲۲} استفاده شده است. تمام الگوهای تحقیق حاضر، با استفاده از تابع RBF با پنج درصد مختلف [(۲۰:۸۰)، (۲۵:۷۵)، (۳۰:۷۰)، (۳۵:۶۵)، (۴۰:۶۰)] و مقادیر γ بهینه شده، مورد ارزیابی گرفت (جدول ۲). برای اینکه به بهترین و دقیق‌ترین پیش‌بینی مدل‌ها دست یافته شود، روند آموزش داده‌ها چندین بار مورد آزمون و خطا قرار گرفت.

Support Vector Machine



شکل ۲- ماشین بردار پشتیبان

همچنین، زمانی که داده‌ها به صورت خطی قابل تفکیک نباشند، باید نگاهی به فضای غیرخطی به خطی، با دخالت تابع کرنل، صورت گیرد. در نهایت، رابطه تفکیک‌کننده به شکل زیر تبدیل می‌گردد [۲۴]:

$$w^T z + b = 0 \rightarrow w^T \phi(x) + b = 0 \quad (۶)$$

در رابطه (۶)، $\phi(x)$ کرنل، $f(x)$ تابع هدف، w ضریب بردار و b مقدار ثابت می‌باشند. وظیفه نگاشت داده‌ها از فضای غیرخطی به فضای خطی را تابع کرنل $\phi(x)$ بر عهده دارد. انواع توابع کرنلی که در SVM استفاده می‌گردد، در جدول ۱ ارائه شده است.

جدول ۱- انواع تابع کرنل [۱۶]

نام تابع کرنل	رابطه کرنل
Linear	$K(x_i, x_j) = x_i^T x_j$
Polynomial	$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d$
Radial basis function	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2)$
Sigmoid	$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$

در جدول ۱، پارامترهای γ و d پارامترهای تابع کرنل هستند. پرکاربردترین توابع کرنل در مسائل SVM توابع گوسین (RBF^{۱۹}) و کرنل حلقوی (ERBF^{۲۰}) می‌باشند و در مسائلی که اطلاعاتی از نوع داده‌ها و طبیعت آنها در دست نباشد، استفاده می‌گردند. برای تابع کرنل RBF، پارامتر γ بهینه می‌شود [۱۶].

²¹- Random Forest

²²- Statistica

¹⁹- Radial Basis Function

²⁰- Exponential Radial Basis Function

جدول ۲- الگوهای بررسی شده در تحقیق حاضر

عمق آبشستگی براساس مدل	پارامتر ورودی
مدل ۱	$(Fr_j, yt/y_j)$
مدل ۲	(Fr_j)
مدل ۳	(yt/y_j)

برتر شناخته شد که معیارهای ارزیابی این مدل برتر در جدول ۳ ارائه شده است. در جدول ۳، از میان ۱۵ مدل کل تحقیق، ۳ مدل برتری که برای ترکیب‌های مختلف به دست آمده‌اند، نمایش داده شده است. در واقع، برای سه ترکیب مختلف به کار رفته، یک مدل برتر برگزیده شد که در جدول ۴ ارائه گردیده است.

مدل شماره ۱، با ترکیب ورودی $(Fr_j, yt/y_j)$ در صورتی که ۸۰ درصد داده‌ها برای مرحله آزمون و ۲۰ درصد داده‌ها برای مرحله آزمایش اختصاص داشت، به عنوان بهترین نتیجه حاصل گردید. با دقت در جدول ۳، مشاهده می‌شود زمانی بهترین پیش‌بینی حاصل می‌شود که دو پارامتر دخیل در عمق نسبی آبشستگی به کار روند. همچنین، تأثیر پارامتر عدد فرود ذره رسوبی نسبت به پارامتر عمق نسبی پایاب در تخمین عمق آبشستگی بیشتر می‌باشد. چنانچه در مدل شماره ۳، با حذف پارامتر عدد فرود ذره از ترکیب ورودی، سبب کاهش چشمگیر دقت پیش‌بینی مدل می‌شود. از لحاظ آزمایشگاهی نیز در یک دبی و عمق پایاب ثابت، با افزایش قطر ذرات رسوبی که منجر به کاهش عدد فرود ذره رسوبی می‌گردد، عمق آبشستگی کاهش می‌یابد. دلیل این امر آن است که ذرات رسوبی درشت‌تر برای شروع حرکت نیاز به تنش برشی بحرانی به مراتب بیشتری نسبت به ذرات با اندازه قطر کوچک‌تر دارند. بنابراین کاهش عدد فرود ذرات رسوبی، سبب کاهش عمق آبشستگی پایین دست سازه شیب‌شکن می‌گردد. در صورتی که با افزایش عمق نسبی پایاب، عمق نسبی آبشستگی تقریباً مستقل از عمق پایاب می‌شود. با افزایش عمق پایاب، درجه استغراق جت ریزشی شیب‌شکن قائم در آب افزایش یافته و مانع از انتشار جت روی بستر رسوبی می‌گردد و بنابراین این امر سبب کاهش عمق نسبی آبشستگی می‌گردد. جهت بررسی بیشتر مدل برتر در تخمین عمق آبشستگی، نتایج حاصل از مدل شماره ۱، برای ۵٪ متفاوت، در جدول ۴ آمده است. ملاحظه می‌شود که برای رسیدن به پیش‌بینی دقیق و نتایج بهتر، مرحله آموزش چندین بار تکرار گردید که از

از میان شاخص‌های ارزیابی متعدد، جهت بررسی نتایج و ارزیابی کارایی مدل‌ها از معیارهای ضریب تعیین R^2 ، خطای جذر میانگین مربعات نرمال‌سازی شده $(NRMSE)^{24}$ ، ضریب کارایی $(DC)^{25}$ و میانگین قدرمطلق خطای نسبی $(MARE)^{26}$ استفاده گردید. ضریب R^2 بیانگر میزان احتمال همبستگی میان مدل و مقدار واقعی می‌باشد و هرچه مقدار آن به عدد یک نزدیک‌تر باشد بهتر است. مقدار $NRMSE$ ابزاری مناسب جهت مقایسه میان مقدار پیش‌بینی شده توسط مدل و مقدار واقعی است. هرچه قدر شاخص $NRMSE$ کوچک‌تر از ۱۰٪ باشد، مدل از دقت بالایی برخوردار است. ضریب کارایی DC همبستگی خطی بین مقادیر اندازه‌گیری و پیش‌بینی را نشان می‌دهد و هرچه قدر مقدار آن به عدد یک نزدیک‌تر باشد، ارتباط بهتر داده‌ها را نشان می‌دهد. هرچه قدر $MARE$ نیز به عدد صفر نزدیک‌تر باشد، مدل دارای دقت بالایی می‌باشد.

۳- نتایج و بحث

برای بررسی عملکرد SVM در تخمین عمق آبشستگی شیب‌شکن قائم از تعداد ۱۰۴ داده مطالعاتی دی و رایکار استفاده شد [۱۰]. مجموعاً ۱۵ مدل، شامل سه مدل و پنج درصد متفاوت که برای هر یک با استفاده از تابع گوسین (RBF) برای مرحله آموزش و آزمون و مقادیر γ بهینه شده (محدوده ۰/۰۱ الی ۱۰۰ در تحقیق حاضر) اجرا شده است. از میان ۵ درصد متفاوت نمونه‌های مورد بررسی، برای هر ترکیب، یک مدل به عنوان مدل

²³- Determination Coefficient

²⁴- The Normalized Root Mean Square Error

²⁵- Nash-Sutcliffe

²⁶- Mean Absolute Relative Error

که مدل شماره ۱، با ترکیب ورودی $(Fr_j, y_j/y_j)$ به لحاظ مقادیر R^2 و DC بیشتر، NRMSE و MARE کمتری در مقایسه با سایر مدل‌ها دارا می‌باشد.

میان الگوهای مختلف، نهایتاً الگوی ۸۰٪ داده‌ها جهت آموزش و ۲۰٪ داده‌ها جهت آزمون به عنوان الگوی برتر انتخاب شد. نتایج به‌دست آمده در جدول ۴ نشان می‌دهد

جدول ۳- خلاصه‌ای از نتایج تمامی مدل‌های برتر تحقیق حاضر

درصد نمونه‌ها	Test				Train				Model
	MARE (%)	NRMSE	DC	R^2	MARE (%)	NRMSE	DC	R^2	
۲۰-۸۰	۱۱/۸۹	۰/۰۷۷۵	۰/۹۲۸	۰/۹۷۸	۹/۰۱	۰/۰۳۴	۰/۹۸۰	۰/۹۸۹	Model 1
۲۰-۸۰	۲۱/۶۱	۰/۱۷۱	۰/۶۲۸	۰/۶۳۷	۱۹/۵۳	۰/۱۵۶۴	۰/۷۶۹	۰/۷۷۴	Model 2
۸۰-۲۰	۲۸/۷۳	۰/۳۱۱	۰/۵۱۳۵	۰/۵۷۱	۳۳/۰۴	۰/۱۶۵	۰/۶۱۱	۰/۶۳۷	Model 3


جدول ۴- نتایج پیش‌بینی عمق نسبی آبستنگی برای مدل برتر

درصد نمونه‌ها	Train				Test				
	R^2	DC	NRMSE	MARE (%)	R^2	DC	NRMSE	MARE (%)	γ
۴۰-۶۰	۰/۹۸۸۹	۰/۹۷۶۹	۰/۰۳۵۸	۹/۹۴	۰/۹۷۱۰	۰/۹۰۳۸	۰/۰۸۷۹	۱۳/۹۱	۳۹
۳۵-۶۵	۰/۹۸۸۸	۰/۹۷۶۱	۰/۰۳۵۹	۹/۹۷	۰/۹۷۱۱	۰/۹۰۳۲	۰/۰۸۸۹	۱۴/۰۸	۳۹
۳۰-۷۰	۰/۹۸۷۸	۰/۹۷۵	۰/۰۳۶۱	۱۰/۲۵	۰/۹۷۵۳	۰/۹۱۲۵	۰/۰۸۶۷	۱۳/۰۶	۳۷
۲۵-۷۵	۰/۹۸۸۹	۰/۹۷۵	۰/۰۳۵۹	۱۰/۲۳	۰/۹۷۶۷	۰/۹۲۲۴	۰/۰۷۸۸	۱۲/۱۹	۳۷
۲۰-۸۰	۰/۹۸۹	۰/۹۸۰	۰/۰۳۴۱	۹/۰۱	۰/۹۷۷۷	۰/۹۲۹	۰/۰۷۷۵	۱۱/۸۹	۳۸


بهبود نتایج معیارهای ارزیابی نسبت به ترکیب مدل‌های دیگر شده است.

در شکل ۳، نمودار مقادیر آزمایشگاهی و پیش‌بینی شده عمق نسبی آبستنگی به ازای تعداد داده، ارائه شده است. با دقت در این شکل می‌توان دریافت که در مرحله آموزش داده‌ها، SVM پیش‌بینی بیشتر از مقدار مشاهداتی داشته است. برای مرحله آزمون نیز در محدوده‌های ابتدایی داده‌های پیش‌بینی بیشتر از مقادیر آزمایشگاهی می‌باشد. در حالی که، در محدوده انتهایی داده‌ها، SVM پیش‌بینی کمتری نسبت به مقادیر واقعی داشته است. در شکل ۴ نیز نمودار پراکنش داده‌های آزمایشگاهی و تخمین زده توسط SVM ارائه شده است که عملکرد قابل قبول روش تحقیق حاضر را نشان می‌دهد. همچنین، مشاهده می‌گردد که نتایج پیش‌بینی شده عمق نسبی آبستنگی پایین‌دست شیب‌شکن توسط SVM در حالت آزمون ($DC=0.929$) نزدیکی خیلی خوبی با حالت آموزش ($DC=0.98$) دارد.

به عبارت دیگر، مدل شماره ۱ جواب‌های قابل قبولی برای برآورد عمق نسبی آبستنگی نشان داده است. بنابراین، مدل شماره ۱ با ۸۰٪ داده‌ها جهت آموزش و با معیارهای آماری نشان داده شده، برای مرحله آزمون به عنوان مدل برتر در تخمین عمق نسبی آبستنگی شناخته شد. براساس نتایج آزمایشگاهی نیز با افزایش عدد فرود ذره (که متناسب با ضخامت ریزش جت و معکوس قطر ذره است)، تنش برشی مورد نیاز برای به حرکت درآوردن ذرات رسوبی افزایش یافته و در نتیجه، عمق آبستنگی افزایش می‌یابد. از طرفی، با افزایش عمق پایاب، از شدت ضربه جت ریزشی به بستر رسوبی کاسته شده و این امر سبب کاهش عمق آبستنگی می‌گردد. بنابراین مشاهده می‌شود که به‌کارگیری پارامترهای ورودی عدد فرود ذره و عمق پایاب در هر پنج درصد مختلف در کنار هم پیش‌بینی‌های مطلوبی ارائه داده است. به بیانی دیگر، استفاده از ترکیب تمامی پارامترها باعث افزایش عملکرد مطلوب و بهتر SVM در تخمین عمق نسبی آبستنگی و

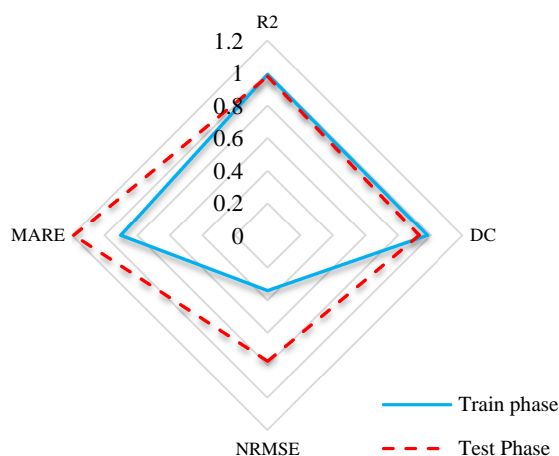


شکل ۳- مقایسه مقادير آزمایشگاهی و پیش‌بینی شده به ازای تعداد داده برای مدل برتر عمق نسبی آبستگي شيبشکن (مراحل آموزش و آزمون)



شکل ۴- مقایسه مقادير آزمایشگاهی و پیش‌بینی شده برای مدل برتر عمق نسبی آبستگي شيبشکن (مراحل آموزش و آزمون)

برای مشاهده بهتر، مقادير اين معيارها در عدد ۱۰ ضرب شده‌اند.



شکل ۵- نمودار راداری از معيارهای ارزیابی برای مدل برتر تحقیق حاضر

همچنين، نمودار تغييرات معيار DC در مقابل گامهای متفاوت برای مدل برتر عمق نسبی آبستگي


در شکل ۵، نمودار راداری بين مقادير آزمایشگاهی و پیش‌بینی شده عمق نسبی آبستگي برای مدل برتر رسم گردیده است. با دقت در اين شکل می‌توان دریافت که مدل SVM در پیش‌بینی عمق نسبی آبستگي عملکرد قابل قبولی داشته است. مقایسه نتایج آزمایشگاهی و تخمین زده شده توسط SVM برای هر دو مرحله آزمون و آموزش حکایت از اين دارد که همبستگي خوبی بين دو سری داده واقعی و پیش‌بینی شده رخ داده است.

از مقادير شاخص‌های ارزیابی بين دو سری داده مشاهداتی و تخمینی ارائه شده در نمودار راداری تحقیق حاضر می‌توان استنباط نمود که SVM قابلیت اعتماد بالایی در پیش‌بینی یک رخداد هیدرولیکی دارد. شایان ذکر است که برای کاهش مقادير NRMSE و MARE و

می‌یابد. همچنین با مشاهده دقیق نمودار استنباط می‌شود که در طول روند شیب‌سازی مدل، آموزش شبکه دچار خطا نشده است و همواره مقادیر آموزش بیشتر از آزمون می‌باشد. در ادامه، جهت بررسی مدل برتر روش ماشین بردار پشتیبان با دیگر الگوریتم‌های یادگیری ماشین از روش جنگل تصادفی برای پیش‌بینی عمق آبشستگی پایین‌دست شیب‌شکن قائم استفاده شد. در این بخش، نتیجه بهترین مدل تخمینی ماشین بردار پشتیبان با نتایج روش جنگل تصادفی مقایسه شد.

برای هر دو مرحله آموزش و آزمون در شکل ۶ نمایش داده شده است. همانگونه که قبلاً اشاره شد، محدوده گام‌های مورد بررسی در تحقیق حاضر از ۰/۰۱ الی ۱۰۰ می‌باشد. با توجه به نمودار مشاهده می‌شود که نمودار ابتدا از گامی ۰/۰۱ الی ۳۸ روندی صعودی داشته و با افزایش پارامتر گاما نتایج داده‌های آموزش و آزمون بهبود یافته و نهایتاً در گامی ۳۸ مقدار بهینه گاما حاصل شده است. به عبارت دیگر، در گامی ۳۸ بهترین پیش‌بینی توسط SVM حاصل شده است.

پس از این مقدار گاما، مقادیر پیش‌بینی تا گامی آخر، که عدد ۱۰۰ می‌باشد، به صورت نزولی کاهش



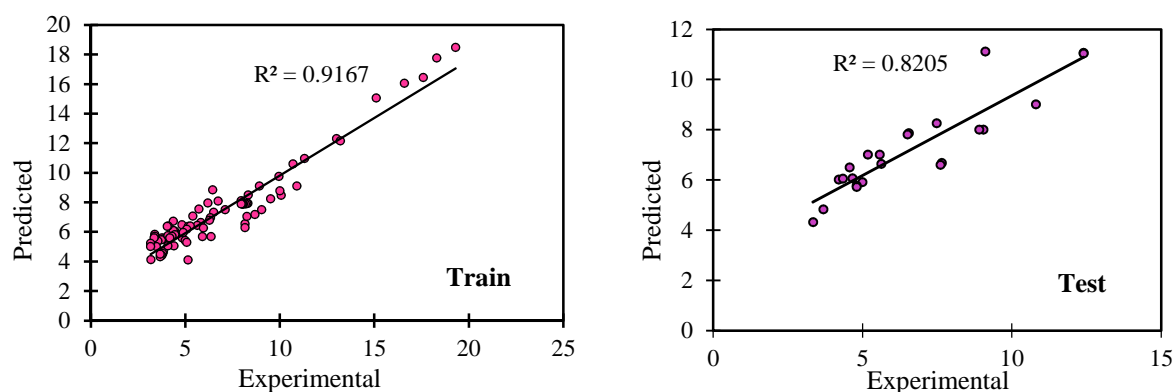
شکل ۶- نمودار تغییرات معیار DC در مقابل گام‌های متفاوت برای مدل برتر عمق نسبی آبشستگی (مراحل آموزش و آزمون)

پایین‌دست شیب‌شکن قائم را تخمین بزند. همچنین نتایج مقایسه مقادیر آزمایشگاهی و پیش‌بینی شده عمق نسبی آبشستگی شیب‌شکن برای مدل جنگل تصادفی در شکل ۷ ارائه شده است. با توجه به شکل مشخص است که با وجود همبستگی خود میان داده‌ها در این روش، اما نتایج پیش‌بینی در مقایسه با روش ماشین بردار پشتیبان با دقت کمی همراه بود.

در جدول ۵ نتایج هر دو روش به همراه معیارهای ارزیابی ارائه شده است. با بررسی دو روش مشخص می‌شود که روش ماشین بردار پشتیبان در مقایسه با نتایج خروجی از روش جنگل تصادفی به مراتب نتایج نزدیکی به مقادیر آزمایشگاهی دارد. روش جنگل تصادفی با وجود خطای قابل قبول و همبستگی مناسب میان داده‌ها ولی نتوانست همانند روش ماشین بردار عمق آبشستگی

جدول ۵- مقایسه نتایج مدل برتر SVM و RF

Test				Train				
MARE (%)	NRMSE	DC	R ²	MARE (%)	NRMSE	DC	R ²	Model
۱۱/۸۹	۰/۰۷۷۵	۰/۹۲۸	۰/۹۷۸	۹/۰۱	۰/۰۳۴	۰/۹۸۰	۰/۹۸۹	SVM
۲۲/۰۶	۰/۱۴۸	۰/۷۴۵	۰/۸۲۱	۲۱/۷۳	۰/۰۷۹	۰/۸۷۸	۰/۹۱۶	RF



شکل ۷- مقایسه مقادیر آزمایشگاهی و پیش‌بینی شده عمق نسبی آبشستگی شیب شکن برای مدل جنگل تصادفی (مراحل آموزش و آزمون)

۴- نتیجه گیری

در آوردن ذرات رسوبی افزایش یافته و در نتیجه، عمق آبشستگی نیز افزایش می‌یابد. از طرفی، با افزایش عمق پایاب، از شدت ضربه جت ریزشی به بستر رسوبی کاسته شده و این امر سبب کاهش عمق آبشستگی می‌گردد. مقایسه نتایج میان مدل برتر روش SVM با نتایج حاصل از روش RF نشان داد که روش SVM در تخمین عمق نسبی آبشستگی از دقت بالایی برخوردار است. نتایج به دست آمده از تحقیق حاضر در مقایسه با داده‌های آزمایشگاهی، نشان از تطابق و هم‌پوشانی بسیار مناسب است و مشاهده شد که روش SVM در پیش‌بینی عمق نسبی آبشستگی خطای کمی داشته و جایگزین مناسبی برای مدل‌سازی آزمایشگاهی و روابط تجربی می‌تواند باشد. همچنین، با توجه به پارامترهای ورودی و نتایج به دست آمده مدل‌های تحقیق حاضر مشخص شد که عدد فرود ذره (Fr_j) تأثیر بیشتری در تخمین عمق نسبی آبشستگی دارد.

در تحقیق حاضر از الگوریتم SVM برای تخمین عمق آبشستگی پایین دست شیب شکن قائم استفاده گردید. برای این منظور از تعداد ۱۰۴ داده آزمایشگاهی استفاده گردید و دو پارامتر عدد فرود ذره رسوبی و عمق نسبی پایاب ($Fr_j, y_t/y_j$) به عنوان ورودی در نظر گرفته شدند. در مجموع ۳ مدل با ۵٪ مختلف برای هر کدام از پارامترها با استفاده از تابع RBF و مقدار بهینه گاما برای مرحله آموزش و آزمون اجرا شد. نتایج نشان داد که مدل شماره ۱ با داده‌های آماری $DC=0.98$, $R^2=0.989$ ، $NRMSE=0.0341$ و $MARE=9.01\%$ برای مرحله آموزش و مقادیر $DC=0.929$, $R^2=0.9777$ ، $RMSE=0.0775$ و $MARE=11.89\%$ برای مرحله آزمون به عنوان مدل برتر در تخمین عمق آبشستگی نسبی شناخته شد. براساس نتایج آزمایشگاهی نیز با افزایش Fr_j (که متناسب با ضخامت ریزش جت و معکوس قطر ذره است)، تنش برشی مورد نیاز برای به حرکت

References

- [1] Daneshfaraz, R., Majedi-Asl, M., Mortazavi, S., & Bagherzadeh, M. (2022). Laboratory evaluation of energy dissipation in the combined structure of the vertical drop with gabion, *Civil Infrastructure Researches*, 8(1), 145-157. doi: 10.22091/cer.2022.7720.1344 [In Persian]
- [2] Bakhmeteff, M.W. (1932). *Hydraulics of open channels*, New York and London, McGraw-Hill book No. 627.13 B34.
- [3] Rand, W. (1955). Flow geometry at straight drop spillways, *In Proceedings of the American Society of Civil Engineers*, 81(9), 1-13.
- [4] Gill, M. A. (1979). Hydraulics of rectangular vertical drop structures, *Journal of Hydraulic Research*, 17(4), 289-302. doi: 10.1080/00221688009499542

- [5] Rajaratnam, N., & Chamani, M. R. (1995). Energy loss at drops, *Journal of Hydraulic Research*, 33(3), 373-384. doi: **10.1080/00221689509498578**
- [6] Esen, I. I., Alhumoud, J. M., & Hannan, K. A. (2004). Energy loss at a drop structure with a step at the base, *Water international*, 29(4), 523-529. doi: **10.1080/02508060408691816**
- [7] Hong, Y. M., Huang, H. S., & Wan, S. (2010). Drop characteristics of free-falling nappe for aerated straight-drop spillway, *Journal of Hydraulic Research*, 48(1), 125-129. doi: **10.1080/00221680903568683**
- [8] Liu, S. I., Chen, J. Y., Hong, Y. M., Huang, H. S., & Raikar, R. V. (2014). Impact characteristics of free over-fall in pool zone with upstream bed slope, *Journal of Marine Science and Technology*, 22(4), 476-486. doi: **10.6119/JMST-013-0604-1**
- [9] Robinson, K. M., Hanson, G. J., & Cook, K. R. (2002). Scour below an overfall: Part I. Investigation, *Transactions of the ASAE*, 45(4), 949-956. doi: **10.13031/2013.9947**
- [10] Dey, S., & Raikar, R. V. (2007). Scour below a high vertical drop, *Journal of Hydraulic Engineering*, 133(5), 564-568. doi: **10.1061/(ASCE)0733-9429(2007)133:5(564)**
- [11] Ghodsian, M., Mehraein, M., & Ranjbar, H. R. (2012). Local scour due to free fall jets in non-uniform sediment, *Scientia Iranica*, 19(6), 1437-1444. doi: **10.1016/j.scient.2012.10.008**
- [12] Emiroglu, M. E., & Tuna, M. C. (2011). The effect of tailwater depth on the local scour downstream of stepped-chutes, *KSCE Journal of Civil Engineering*, 15(5), 907-915. doi: **10.1007/s12205-011-0921-6**
- [13] Chen, J. Y., Hsu, H. H., & Hong, Y. M. (2016). The influence of upstream slope on the local scour at drop structure, *Journal of Mountain Science*, 13(12), 2237-2248. doi: **10.1007/s11629-015-3790-5**
- [14] Maleki, S., & Fiorotto, V. (2019). Scour due to a Falling Plane Jet: A Comprehensive Approach, *Journal of Hydraulic Engineering*, 145(4), 04019008. doi: **10.1061/(ASCE)HY.1943-7900.0001564**
- [15] Akib, S., Mohammadhassani, M., & Jahangirzadeh, A. (2014). Application of ANFIS and LR in prediction of scour depth in bridges, *Computers & Fluids*, 91, 77-86. doi: **10.1016/j.compfluid.2013.12.004**
- [16] Roushangar, K., & Koosheh, A. (2015). Evaluation of GA-SVR method for modeling bed load transport in gravel-bed Rivers, *Journal of Hydrology*, 527, 1142-1152. doi: **10.1016/j.jhydrol.2015.06.006**
- [17] Hoang, N. D., Liao, K. W., & Tran, X. L. (2018). Estimation of scour depth at bridges with complex pier foundations using support vector regression integrated with feature selection, *Journal of Civil Structural Health Monitoring*, 8(3), 431-442. doi: **10.1007/s13349-018-0287-2**
- [18] Naderpour, H., Rafiean, A. H., & Fakharian, P. (2018). Compressive strength prediction of environmentally friendly concrete using artificial neural networks, *Journal of Building Engineering*, 16, 213-219. doi: **10.1016/j.jobe.2018.01.007**
- [19] Majedi-Asl, M., Daneshfaraz, R., Fuladipanah, M., Abraham, J., & Bagherzadeh, M. (2020). Simulation of bridge pier scour depth base on geometric characteristics and field data using support vector machine algorithm, *Journal of Applied Research in Water and Wastewater*, 7(2), 137-143. doi: **10.22126/arww.2021.5747.1189**
- [20] Daneshfaraz, R., Bagherzadeh, M., Esmaeeli, R., Norouzi, R., & Abraham, J. (2021). Study of the performance of support vector machine for predicting vertical drop hydraulic parameters in the presence of dual horizontal screens, *Water Supply*, 21(1), 217-231. doi: **10.2166/ws.2020.279**
- [21] Daneshfaraz, R., Aminvash, E., Ghaderi, A., Abraham, J., & Bagherzadeh, M. (2021b). SVM performance for predicting the effect of horizontal screen diameters on the hydraulic parameters of a vertical drop, *Applied sciences*, 11(9), 4238. doi: **10.3390/app11094238**
- [22] Bagherzadeh, M., Mousavi, F., Manafpour, M., Mirzaee, R., & Hoseini, K. (2022). Numerical simulation and application of soft computing in estimating vertical drop energy “dissipation with horizontal serrated edge”, *Water Supply*, 22(4), 4676-4689. doi: **10.2166/ws.2022.127**
- [23] Asadi, M. E., Naeeni, S. T. O., & Kerachian, R. (2022). The effects of splitters on the downstream scour hole of overflow spillways: application of support vector regression, *Water Supply*, 22(2), 1905-1929. doi: **10.2166/ws.2021.310**
- [24] Roushangar, K., Alami, M. T., Shiri, J., & Asl, M. M. (2018). “Determining discharge coefficient of labyrinth and arced labyrinth weirs using support vector machine”, *Hydrology Research*, 49(3), 924-938. doi: **10.2166/nh.2017.214**
- [25] Vapnik, V. (1998). *Statistical learning theory* Wiley. New York, 1, ISBN: 978-0-471-03003-4.
- [26] Dasineh, M., Ghaderi, A., Bagherzadeh, M., Ahmadi, M., & Kuriqi, A. (2021). “Prediction of Hydraulic Jumps on a Triangular Bed Roughness Using Numerical Modeling and Soft Computing Methods”, *Mathematics*, 9(23), 31-35. doi: **10.3390/math9233135**
- [27] Breiman, L. (1999). *Random forests; uc berkeley tr567*. University of California: Berkeley, CA, USA.